

Exploración de Sistemas Recomendadores para la Recomendación de Propuestas en Organizaciones Autónomas Descentralizadas

Máster Universitario en Inteligencia Artificial

David Davó Laviña²

Tutores: Damiano Zanardini¹ Javier Arroyo²

¹Departamento de Inteligencia Artificial, Universidad Politécnica de Madrid

²Departamento de Ingeniería del Software e Inteligencia Artificial, Universidad Complutense de Madrid

Junio 2024



Índice

1 Introducción

- DAOs y Blockchain
- Motivación
- Sistemas Recomendadores

2 Experimento

- Conjunto de datos
- Entrenamiento y validación

3 Modelos

- Modelo basado en contenido
- Modelo basado en filtrado colaborativo
- Modelo híbrido

4 Resultados

5 Conclusiones



Organización Autónoma Descentralizada (DAO)

Tipo de organización que permite la coordinación de proyectos mediante un proceso de **votación** democrático utilizando la tecnología **blockchain**¹.

¹Hassan y Filippi (2021)



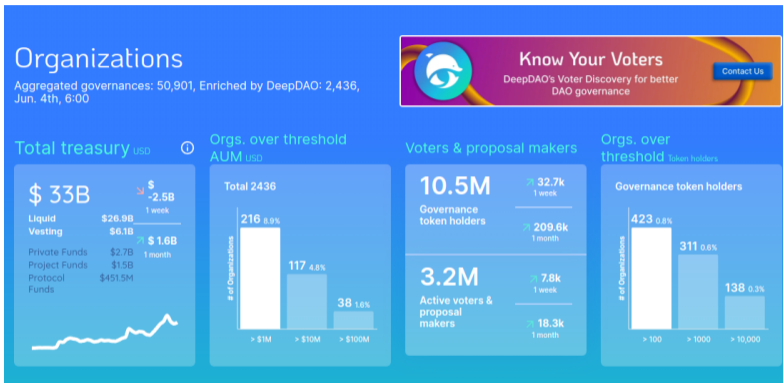


Figura: Captura de pantalla del portal de analíticas Deepdao¹

¹<https://deepdao.io/organizations>

Blockchain


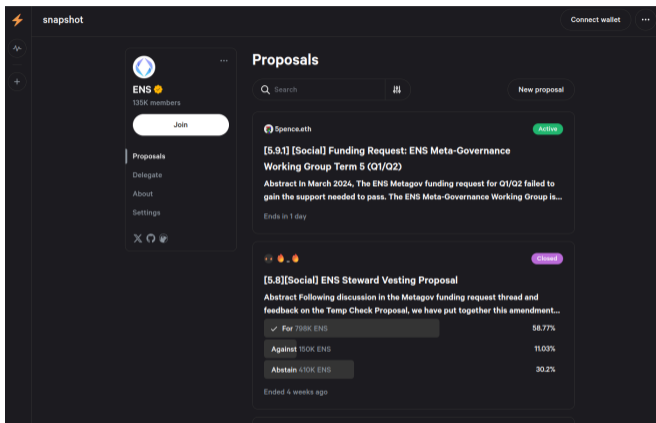


Figura: Representación de una cadena de bloques



The screenshot shows the Snapshot interface for the ENS DAO. On the left, there is a sidebar with the ENS logo, a 'Join' button, and a menu with options: Proposals, Delegate, About, and Settings. The main area is titled 'Proposals' and features a search bar and a 'New proposal' button. Two proposals are listed:

- [5.9.1] [Social] Funding Request: ENS Meta-Governance Working Group Term 5 (Q1/Q2)** (Active)
Abstract In March 2024, The ENS Metagov funding request for Q1/Q2 failed to gain the support needed to pass. The ENS Meta-Governance Working Group is...
Ends in 1 day
- [5.8][Social] ENS Steward Vesting Proposal** (Closed)
Abstract Following discussion in the Metagov funding request thread and feedback on the Temp Check Proposal, we have put together this amendment...
For 798K ENS: 58.77%
Against 150K ENS: 11.03%
Abstain 410K ENS: 30.2%
Ended 4 weeks ago

Figura: Captura de pantalla de la interfaz de votación de la DAO del protocolo ENS.
<https://snapshot.org/#/ens.eth>



- **Baja participación:** Menos de la mitad de usuarios han votado alguna vez¹
- **Gran volumen de propuestas:** 150 propuestas/7 días en PancakeSwap o 70 en Decentraland²
- **Sin personalización**³

¹Arroyo, Javier et al. «DAO-Analyzer: Exploring Activity and Participation in Blockchain Organizations». 2022

²Notebook: 04c_dao-census-onedao.ipynb

³Aviv, Eylon. «All the ways we have fucked up governance, and how to rethink it from first principles with Eylon». 2023



DAOs y sistemas recomendadores




Figura: Representación de una DAO como un grafo bipartito

- Usuarios
- Propuestas (*ítems*)
 - Descripción y texto
 - Tiempo de apertura
 - Tiempo de cierre
- Votos (*Interacción*)
 - Timestamp



DAO census¹

- 30 000 DAOs
- 5 millones de votantes
- 22 millones de votos emitidos
- 180 mil propuestas

DAO	Props.	Usu.	Vot.	% ₀₀ Dns.
DEAD Foundations	5 591	3k	18k	1.83
PancakeSwap	2 691	130k	533k	3.05
<i>Decentraland</i>	2 060	7k	117k	15.47
AAVE	1 140	87k	2.3M	47.28
MetaCartel	934	200	3k	35.38

Tabla: Resumen de datos de algunas DAOs

¹Davó, David et al. *DAOs Census TFM*. 2023



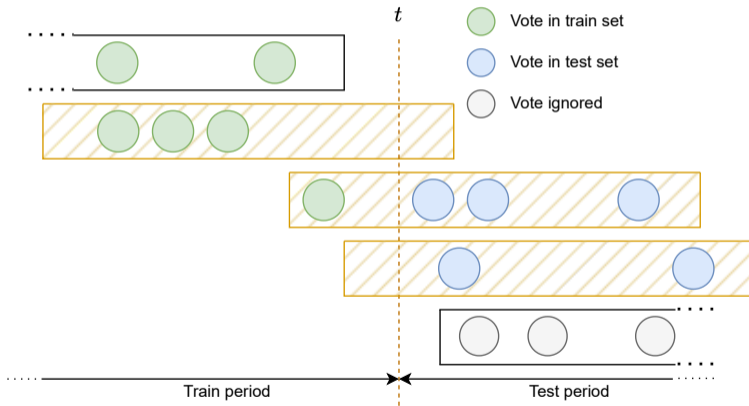
Decentraland

- El 50% de los 7k usuarios han votado como mucho en 3 propuestas
- Las propuestas duran 7 o 14 días
- Media de 56 votos por propuesta
- Picos de hasta 70 propuestas
- Se suelen votar poco después (48 horas) de su fecha de creación
- Las propuestas no se crean uniformemente a lo largo del día de la semana



Fuente: Figuras 4.3 a 4.6 de la memoria

División en entrenamiento y prueba



Folds utilizados

Semana	P.A.	Votos	Usuarios	vpp	vpv
2023-W19	18	354	139	19.67	2.55
2023-W20	25	811	169	32.44	4.80
2023-W21	19	332	122	17.47	2.72
2023-W22	13	289	101	22.23	2.86
2023-W23	13	341	118	26.23	2.89
2023-W24	16	391	132	24.44	2.96
2023-W25	17	360	148	21.18	2.43
2023-W26	10	239	107	23.90	2.23
2023-W27	21	890	249	42.38	3.57
2023-W28	23	384	142	16.70	2.70

Tabla: Características de los datos en evaluación de los folds utilizados



Métricas utilizadas

- $precision@k$
- $recall@k$
- $nDCG@k$
- $MAP@k$

Cuidado con $k > |\text{items rel. en top } k|$

$$precision@k = \frac{|\text{items rel. en top } k|}{k} \quad (1)$$



La línea base *OpenPop*

Most Popular no tiene en cuenta:

- La popularidad en ese momento dado
- Si el ítem estaba disponible
- Que la prop. puede estar cerrada

OpenPop

Dado un instante t , recomendar la propuesta **abierta** más votada en ese momento siempre que el usuario no haya votado ya en ella.



- **Basado en contenido:** PLN del texto de las propuestas
- **Basado en filtrado colaborativo:** Graph Neural Networks (LightGCN)
- **Híbrido:** *Ensemble* de los dos anteriores



Modelos del lenguaje

- Usando título y descripción de cada propuesta
- Python's Sentence Transformers (SBERT): `all-mpnet-base-v2` (768 dims)
- Importante: Utilizar tokenizador probabilístico

- ¿Cómo usamos los embeddings?



Ejemplo

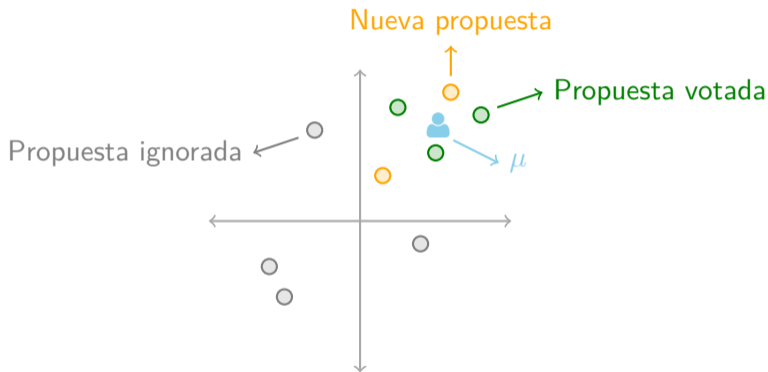


Figura: Representación simplificada del espacio latente del texto de las propuestas de un usuario

Fine-tuning del PLN

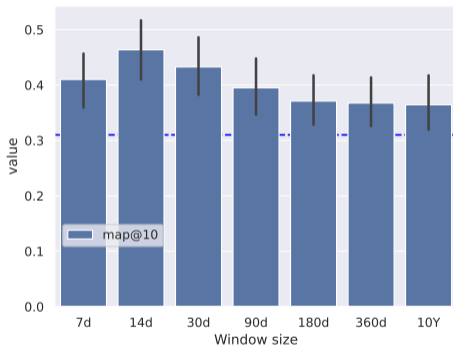


Figura: Rendimiento del modelo PLN con respecto al número de días utilizados para crear el modelo del usuario




Graph Neural Networks

- SOTA en Sistemas Recomendadores
- Grafo Bipartito → Link prediction
- Nodo → Embedding



LightGCN



Light Graph Convolution

$$e_u^{(k+1)} = \sum_{i \in \mathcal{N}} \frac{1}{\sqrt{|\mathcal{N}_u|} \sqrt{|\mathcal{N}_i|}} e_i^{(k)}$$

Embedding final

$$e_u = \sum_{k=0}^K e_u^{(k)}; \quad e_i = \sum_{k=0}^K e_i^{(k)}$$

He, Xiangnan et al. «LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation». 2020



Fine-tuning de LightGCN I

Hiperparámetro	Valores	Muestreo
Embedding dim.	$1 \leq e \leq 1024, e \in \mathbb{N}$	Loguniforme
Convolution layers	$c \in \{1, 2, 3, 4, 5, 6\}$	Uniforme
Batch size	$bs \in \{64, 128, 256, 512, 1024\}$	Uniforme
Learning rate	$10^{-4} \leq lr \leq 1, lr \in \mathbb{R}$	Loguniforme
L2 regularization	$10^{-7} \leq l2 \leq 10^{-2}, l2 \in \mathbb{R}$	Loguniforme


Tabla: Espacio de búsqueda de hiperparámetros para LightGCN

Bergstra, James et al. «Making a Science of Model Search: Hyperparameter Optimization in Hundreds of Dimensions for Vision Architectures». 2013



Liaw, Richard et al. «Tune: A Research Platform for Distributed Model Selection and Training». 2018

Elección de hiperparámetros



Resultados GNN




Figura: precision@5 del modelo GNN




Figura: ndcg@10 del modelo GNN



Comparación recomendaciones




Figura: Porcentaje de propuestas en común entre los dos recomendadores



Métodos de fusión

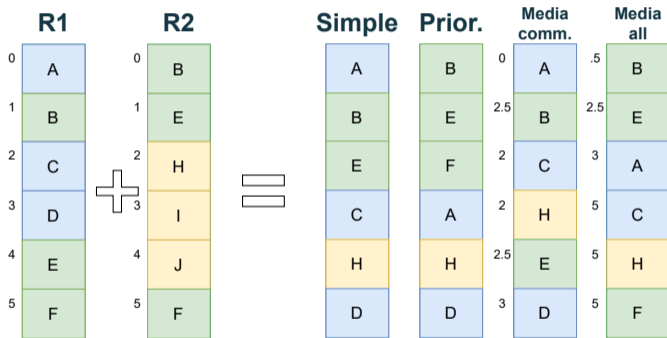


Figura: Distintos métodos de fusión utilizados



Decentraland

Modelo	precision@5
OpenPop	0.221
GNN	0.271
avg.	0.287
naive	0.289
prioritize	0.291
avg. all	0.292
NLP	0.295

Tabla: Media de los folds






Figura: Resultados en cada fold de los sistemas recomendadores




Otras organizaciones




(a) Decentraland



(b) DEAD Foundations



(c) Metacartel



(d) PancakeSwap

Figura: Resultados de la métrica ndcg@10 en las organizaciones probadas.



Trabajo realizado

- Recuperación, ampliación y publicación del dataset¹
- Creación de benchmark *OpenPop*
- Evaluación: división en entrenamiento y prueba considerando el tiempo de apertura y cierre
- Desarrollo y modificación de los modelos²
- Elección de hiperparámetros evitando fugas
- No solo para DAOs: También podría usarse en **recomendación de eventos**

¹Davó, David et al. *DAOs Census TFM*. 2023

²Davó, David. *daviddavo/upm-tfm-notebooks: Notebooks to explore the creation of a RecSys for DAOs*.

2024



Limitaciones

- Evaluación offline → ¿Cómo se comportará en realidad?
- Modelo GNN re-entrenado cada fold
- Simulación discretizada



Trabajo futuro

- Exploración de otros modelos
 - Tener en cuenta el tiempo
 - Expandir el grafo utilizado
- Evaluación
- Elección de hiperparámetros
- Despliegue descentralizado¹

¹Patel, Anirudh et al. *The Graph as AI Infrastructure*. 2024



Preguntas

- Modelos:  [daviddavo/upm-tfm-notebooks](#)
- Diapositivas:  [daviddavo/upm-tfm-presentacion](#)

Esta obra está bajo una licencia Creative Commons «Atribución 4.0 Internacional».



Referencias I

- 📄 Hassan, Samer y Primavera De Filippi (20 de abr. de 2021). «Decentralized Autonomous Organization». En: *Internet Policy Review* 10.2. 122 citations (CrossRef 2024/5/19). ISSN: 2197-6775. DOI: 10.14763/2021.2.1556.
- 📄 Arroyo, Javier et al. (8 de nov. de 2022). «DAO-Analyzer: Exploring Activity and Participation in Blockchain Organizations». En: *Companion Publication of the 2022 Conference on Computer Supported Cooperative Work and Social Computing. CSCW'22 Companion*. 2 citations (CrossRef 2024/5/19). New York, NY, USA: Association for Computing Machinery, págs. 193-196. ISBN: 978-1-4503-9190-0. DOI: 10.1145/3500868.3559707.
- 📄 Aviv, Eylon (5 de mar. de 2023). «All the ways we have fucked up governance, and how to rethink it from first principles with Eylon».
- 📄 Davó, David y Andrew Schwartz (2023). *DAOs Census TFM*. DOI: 10.34740/kaggle/dsv/8413149



Referencias II

- 📄 Rendle, Steffen, Li Zhang y Yehuda Koren (3 de mayo de 2019). *On the Difficulty of Evaluating Baselines: A Study on Recommender Systems*. DOI: [10.48550/arXiv.1905.01395](https://doi.org/10.48550/arXiv.1905.01395).
- 📄 Ji, Yitong et al. (25 de jul. de 2020). «A Re-visit of the Popularity Baseline in Recommender Systems». En: *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. SIGIR '20. 20 citations (CrossRef 2024/5/19). New York, NY, USA: Association for Computing Machinery, págs. 1749-1752. ISBN: 978-1-4503-8016-4. DOI: [10.1145/3397271.3401233](https://doi.org/10.1145/3397271.3401233).
- 📄 He, Xiangnan et al. (25 de jul. de 2020). «LightGCN: Simplifying and Powering Graph Convolution Network for Recommendation». En: *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. SIGIR '20. 1532 citations (CrossRef 2024/5/19). New York, NY, USA: Association for Computing Machinery, págs. 639-648. ISBN: 978-1-4503-8016-4. DOI: [10.1145/3397271.3401063](https://doi.org/10.1145/3397271.3401063).



Referencias III

- 📄 Bergstra, James, Daniel Yamins y David Cox (13 de feb. de 2013). «Making a Science of Model Search: Hyperparameter Optimization in Hundreds of Dimensions for Vision Architectures». En: *Proceedings of the 30th International Conference on Machine Learning*. International Conference on Machine Learning. ISSN: 1938-7228. PMLR, págs. 115-123.
- 📄 Liaw, Richard et al. (13 de jul. de 2018). «Tune: A Research Platform for Distributed Model Selection and Training». En: 31 citations (INSPIRE 2024/5/19) 31 citations w/o self (INSPIRE 2024/5/19). DOI: 10.48550/arXiv.1807.05118.
- 📄 Davó, David (2024). *daviddavo/upm-tfm-notebooks: Notebooks to explore the creation of a RecSys for DAOs*.
- 📄 Patel, Anirudh, Sam Green y Eva Beylin (28 de mayo de 2024). *The Graph as AI Infrastructure*. White Paper.

